

一般物体認識のための物体領域の抽出手法に関する研究

伊東 靖簡[†] 猿田 和樹^{††} 寺田 裕樹^{††} 武田 和時^{††}

[†] 秋田県立大学大学院システム科学技術学研究科電子情報システム学専攻
秋田県由利本荘市土谷字海老ノ口 84-4

^{††} 秋田県立大学システム科学技術学部電子情報システム学科
秋田県由利本荘市土谷字海老ノ口 84-4

E-mail: †{m09b002,saruta,terata,takeda}@akita-pu.ac.jp

あらまし 一般物体認識とは、実世界シーンの画像を一般名称で認識する技術である。本研究では、画像中からクラスに関係なく物体領域を抽出する手法を提案する。提案手法は、学習プロセスにおいて、物体のクラスを認識する識別器だけでなく、入力画像に対して物体領域と非物体領域を判定・検出する検出器を生成する。標準評価画像データセットを対象にした認識実験において、提案手法の検出精度と認識精度の性能評価を行い、従来手法と同等の認識精度を得ることで提案手法の有効性を確認した。

キーワード Object Filter, 一般物体認識, HOG, SVM, Caltech101

A Study on the Object Extraction Method for Generic Object Recognition

Yasuhiro ITO[†], Kazuki SARUTA^{††}, Yuki TERATA^{††}, and Kazutoki TAKEDA^{††}

[†] Graduate School of Systems Science and Technology Akita prefectural University
015-0055 84-4 Tuchiya, ebinobuchi, Yurihonjo, Akita

^{††} Systems Science and Technology Akita prefectural University
015-0055 84-4 Tuchiya, ebinobuchi, Yurihonjo, Akita

E-mail: †{m09b002,saruta,terata,takeda}@akita-pu.ac.jp

Abstract Generic Object Recognition means that the computer recognize the object classes in natural images. In this paper, we propose the method which can extract the region around object in the images without object class. We don't only train class classifier, but also object detector which can distinguish object and non-object regions in training process. We proved our proposed method achieve high accuracy of detection and recognition on the image database.

Key words Object Filter, 一般物体認識, HOG, SVM, Caltech101 Object Filter, Generic Object Recognition, HOG, SVM, Caltech101

1. はじめに

近年、デジタルカメラ等の普及により、個人が大量のデジタル画像を蓄積することが可能になった。しかし、計算機が画像の意味内容を理解できないため、画像の管理には人手の介入が不可欠となる。そのため、人と計算機の視覚情報処理のギャップを狭める技術として、一般物体認識が必要とされる [1]。

一般物体認識は、実世界シーンの画像の対象物を一般名称で認識する技術であり、画像認識において最も困難な課題の一つとされている。その応用技術に画像の自動

キーワード付け・画像検索等が挙げられる。現在、この研究分野では、Caltech101 データセットを対象にした認識実験が盛んに行われており、画像を局所パターンの集合で表現する Bag-of-keypoint 用いた手法や対象物が画像中の中心にあるという位置情報を考慮し、重み付けを行う Spatial Marching 等が有名である [2], [3]。さらに、Varma らは、各クラス識別器に応じて複数の特徴量の重み付けを変えて併用することにより、認識率としては最高の 90% を達成している [4]。このように、認識率は向上傾向にあるが、現状の技術では画像中の物体の位置までは推定できていない。

本研究では、入力画像中の物体のクラスを認識する前に、クラスに関係なく物体の位置推定を可能にし、本来の意味での画像認識へ発展させる。そのための物体領域の抽出手法を提案し、その有効性について検討する。また、画像中から物体領域を検出することで、背景の影響を吸収させることによる認識率の向上を検討する。

2. Histogram of Oriented Gradient

Histogram of Oriented Gradient(以下, HOG) は、局所領域における輝度の勾配方向をヒストグラム化した特徴量である。局所的な幾何学的変化と明度変化に不変であり、大まかな形状特徴を表現可能とし、人・車検出に有効性が報告されている [5], [6]。以下に本研究で用いる改良型の HOG の抽出処理を示す [7]。

2.1 輝度勾配算出

各ピクセルの輝度から勾配強度 m と勾配方向 θ を式 (1)~ (3) より算出する。

$$m(u, v) = \sqrt{f_u(u, v)^2 + f_v(u, v)^2} \quad (1)$$

$$\theta(u, v) = \tan^{-1} \left(\frac{f_v(u, v)}{f_u(u, v)} \right) \quad (2)$$

$$\begin{cases} f_u(u, v) = I(u+1, v) - I(u-1, v) \\ f_v(u, v) = I(u, v+1) - I(u, v-1) \end{cases} \quad (3)$$

2.2 セルによるヒストグラム化

HOG 算出のためのセル分割とブロックのヒストグラムを図 7 に示す。本研究では図 1(a) のように、画像の縦、横を l 等分し、 $l \times l$ セルに分割する。HOG 特徴量は算出された m, θ を用いて、図 1(b) のように生成したセル毎に 8 方向の輝度勾配方向ヒストグラムを作成する。輝度の勾配方向ヒストグラムは、 $0^\circ \sim 180^\circ$ を 22.5° ずつ分割し、8 方向の勾配方向ヒストグラムとする。

2.3 ブロックによる正規化

各セルで作成した輝度の勾配方向ヒストグラムを 3×3 セルを 1 ブロックとして式 (4) で正規化する。セル (i, j) の特徴量を $F_{i, j} = [f_1, f_2, \dots, f_8]$ とすると、 k 番目のブロックの特徴量 (72 次元) は、 $V_k = [F_{i, j}, \dots, F_{n, n}]$ と表すことができる。この正規化処理をブロックを 1 セルずつ移動するたびに行う。そのため、図 1(c) 特徴量は異なるブロックの領域によって何度も正規化される。本研究では、入力画像を 8×8 セルに分割するため、縦方向に 6 ブロック、横方向に 6 ブロック合計 36 ブロックに対して正規化を行う。各ブロック毎に正規化された HOG 特徴量は、36 ブロック \times 72 次元 = 2592 次元となる。

$$v = \frac{f}{\sqrt{\|V_k\|_2^2 + \epsilon}} \quad (\epsilon = 1) \quad (4)$$

3. Object Filater の提案

本研究では、物体領域の検出器として“Object Filter”

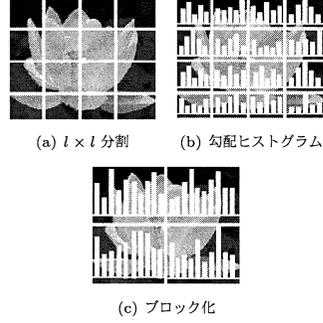


図 1 セル分割とブロックのヒストグラム

を提案する。学習プロセスと認識プロセスの入力画像に関する事前情報の違いから、提案する Object Filter は学習用 Object Filter と認識用 Object Filter に分かれる。各 Object Filter の生成方法と学習・認識処理プロセスにおける使用方法を以下に示す。

3.1 物体を含む部分領域間の距離特性

本研究では、学習・認識時に画像から物体を含む Region Of Interest (ROI) を決定する。学習プロセスのように、教師情報から画像のクラスが既知であっても、1 枚の画像から画像中の物体領域を含む ROI を決定することは困難である。しかし、複数の画像を与えることにより、各々の画像の類似した部分領域から物体の位置を推定し、ROI を決定できると考えられる。

そこで、同一クラスの複数の画像間において、特徴空間上で物体を含む部分領域間の距離が小さくなると仮説する。この仮説の検証のため、画像中の物体の位置や大きさに多様性があるクラスの代表として、“chair” “Faces” “soccer_ball” を対象に、画像間の物体領域と物体領域、物体領域と非物体領域、背景領域と非物体領域に対して特徴空間上 (HOG 特徴空間) での距離を式 (5)~ (6) で求める。実験結果を表 1 に示す。実験には、各クラス 10 枚の画像を用い、目視により、物体領域と非物体領域を複数選択し、全ての組合せで互いの特徴空間上での距離を計算する。これを、すべてのペア 45 組で平均距離を計算する。表 1 で示す値は、式 (7) で最小値 0、最大値 1 に正規化した 45 組の平均距離である。式 (7) で max はクラスにおいて計算した全ての距離の最大値を示し、min は最小値を示す。表 1 より、3 つのクラスにおいて、物体領域と非物体領域、非物体領域と非物体領域よりも、物体領域と物体領域の距離が小さいことがわかる。これより、画像間において物体領域同士の特徴空間での距離は他の領域間に比べ小さくなることを確認した。

$$\chi^2(x, y) = \sum_{i=0}^d \frac{(x_i - y_i)^2}{x_i + y_i} \quad (5)$$

$$d(X, Y) = (\chi^2(x, y))^2 \quad (6)$$

表 1 物体領域と非物体領域の距離

クラス	物体と物体	物体と非物体	非物体と非物体
chair	0.35	0.42	0.46
Faces	0.25	0.42	0.44
soccer_ball	0.37	0.48	0.51

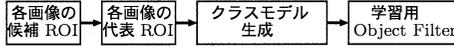


図 2 学習用 Object Filter 生成までの流れ

$$Q(d(X, Y)) = \frac{d(X, Y) - \min}{\max - \min} \quad (7)$$

3.2 学習用 Object Filter

3.1 の特性を基に学習用 Object Filter を生成する。学習プロセスでは、入力画像のクラスは既知であるが、物体の位置が未知の状況から ROI を決定する必要がある。そのための ROI 検出器が学習用 Object Filter である。学習用 Object Filter 生成の流れを図 2 に示す。図 2 のように、初めに 1 枚の画像から複数の物体候補領域 (候補 ROI) を生成し、その中から各画像の代表領域 (代表 ROI) を決定する。クラス毎に代表 ROI からクラスモデルを作成し、学習用 Object Filter に用いる。各ステップでの処理内容を以下に示す。

3.2.1 候補 ROI の生成

画像中の物体の大きさは未知であるため、候補 ROI の生成に関しては、複数の大きさの ROI を走査する必要がある。その一方で、部分領域間の距離を比較するには、抽出される特徴量の次元数が等しくなければならない。そこでまず、図 3 のように入力画像に対して、横を N_1 等分、縦を N_2 等分し、1 区画を 1 セルとして、 $N_1 \times N_2$ セルに画像を分割する。これを N_1, N_2 を変えて複数パターン用意する。最も少ないセル数で分割した画像 (図 3 では 8×8 セル) を基準として、この基準となるセル数で構成される領域を 1 つの候補 ROI とする。基準となる分割セル数以上で分割された画像に対しては、図 3 に示すように、候補 ROI を示すウィンドウを用意し、初期位置を画像の左上に設定し、1 セルずつスライドさせ、 $M \times M$ セル分の領域を候補 ROI として複数生成する。

3.2.2 代表 ROI の生成

3.2.1 で生成した候補 ROI のうち、同一クラスの物体を中心に含む ROI 間の特徴空間上での距離は、表 1 のように近くなる。そこで、特徴空間上での画像同士の距離関数 $d(X, Y)$ を式 (5), (6) で計算し、ある画像から生成される r 個の候補 ROI と他の画像から生成される r 個の候補 ROI の距離 $d(X, Y)$ を全ての組合せで算出し、距離が最小になる場合の互いの候補 ROI を代表 ROI として決定する。本研究では、クラス毎に学習画像 N 枚用意して、各画像から r 個の候補 ROI を抽出する。次に式 (8) のコスト関数 C を最小化する候補 ROI を求め、各画像の代表 ROI とする [8]。クラス毎に代表 ROI を用い

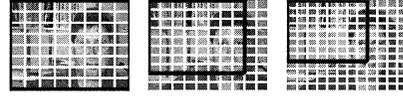


図 3 候補 ROI の生成

て、クラスモデルを生成する。このクラスモデルは代表 ROI から抽出される特徴量の平均値であり、これを学習用 Object Filter として次のように学習に用いる。学習プロセスでは、入力画像から候補 ROI を生成し、特徴空間上で、候補 ROI と入力画像が属するクラスのクラスモデル間の距離 $d(X, Y)$ が最小になる候補 ROI を ROI として決定する。この ROI を学習サンプルとして用い、クラス識別器を学習する。

$$C = \sum_{X \subseteq N} \sum_{Y \subseteq N} d(X_{r_i}, Y_{r_j}) \quad (8)$$

3.3 認識用 Object Filter

認識プロセスでは、入力画像に対する教師情報等の事前情報もないため、入力画像の物体のクラスと位置が未知の状況から、物体領域を含む ROI を決定しなければならない。そのため、クラスに関係なく入力画像から物体領域を検出する検出器が必要となる。本研究では、この検出器を認識用 Object Filter と呼ぶ。学習プロセスにおいて、学習用 Object Filter を利用してクラス識別器を生成すると同時に、認識用 Object Filter を生成する。認識用 Object Filter 生成の流れを図 4 に示す。図 4 のように、初めに学習用 Object Filter を利用して、学習画像から物体の ROI と非物体の ROI を選択する。この 2 種類の ROI を用いて、認識用 Object Filter を作成する。各ステップの処理内容を以下に示す。

3.3.1 物体および非物体領域の抽出

初めに、学習用 Object Filter の生成時と同様に、学習用画像から候補 ROI を生成する。学習用 Object Filter を用い、特徴空間上で候補 ROI と入力画像が属するクラスモデル間の距離 $d(X, Y)$ を求める。この距離関数 $d(X, Y)$ が最小となる候補 ROI を positive ROI (物体領域、以下、p-ROI)、最大になる候補 ROI を negative ROI (非物体領域、以下、n-ROI) として決定する。図 5 に、n-ROI と p-ROI の例を示す。

3.3.2 SVM による 2 クラス学習

学習プロセスで用いる全画像から、クラスに関係なく 3.3.1 のように p-ROI と n-ROI を選択する。得られた p-ROI と n-ROI を SVM を用いて学習し、物体と非物体の ROI を決定する 2 クラス識別器を生成し、これを認識用 Object Filter とする。ここで、p-ROI と n-ROI を選択する際に、クラスモデルとの距離が小さい順に p 個、大きい順に n 個の ROI を選択することで、p-ROI と n-ROI の学習比率を変えることができる。



図 4 認識用 Object Filter 生成の流れ

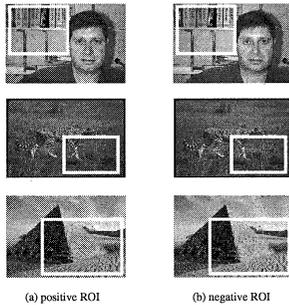


図 5 positive・negative ROI の例

3.4 認識用 Object Filter を用いた認識処理

3.2, 3.4 では、Object Filter の生成方法について述べた。ここで、全体的な学習プロセスのフローチャートを図 6 に示す。従来の学習プロセスでは物体を識別するためのクラス識別器のみを生成するのに対して、本研究では、図 6 のように、クラス識別器だけでなく物体領域を検出する Object Filter を生成する。また、本研究での認識処理の流れを図 7 に示す。図 7 のように、入力画像から生成される候補 ROI に認識用 Object Filter を適用して、SVM 出力値が最も高い候補 ROI を ROI として決定する。この ROI に含まれる物体のクラスをクラス識別器により判定する。

4. 認識実験

本研究では、提案する Object Filter を用いた実験により、検出精度および認識精度の評価を行う。クラス識別器にはガウスクERNELを用いた Support Vector Machine [9] (以下、SVM) を one-versus-one で用いる。なお、実装には Intel 社の画像処理ライブラリである OpenCV [10] を用いる。

4.1 実験データ (Caltech101)

実験には、Caltech101 画像データセットを使用する。これはカリフォルニア工科大学で作成された一般物体認識の研究で用いられている評価画像データセットである。中身は、101 クラスの画像からなり、人手で集めた 9144 枚の画像から構成される。クラス毎に保有する枚数が異なり、31~800 枚までとばらつきがある。実験においては、クラス毎ランダムに 30 枚選択し、学習画像として用い、残りのうち 20 枚を評価画像として用いる。残りの画像が 20 枚に満たないクラスに関しては、残り全ての画像を評価画像として用いる。

4.2 Object Filter による検出精度評価実験

本研究で提案した Object Filter による物体の検出実験を行った。この実験は、画像中の物体領域を正確に検

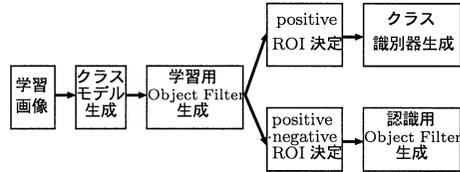


図 6 2 種類の Object Filter の生成処理

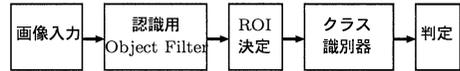


図 7 認識処理の手順

表 2 Object Filter による物体領域の検出精度

Object Filter	学習用 Object Filter	認識用 Object Filter
検出率 [%]	71.1	67.5

表 3 認識用 Object Filter の生成条件の違いによる検出精度

positive-negative ROI の比率	1:1	1:2	2:1
検出率 [%]	67.5	67.9	66.5

出できているかどうかを目視により判定する。実験結果を表 2 に示す。表 2 より、認識用 Object Filter よりも学習用 Object Filter の方が検出率が高くなることが確認された。これは、学習用 Object Filter 使用時には、入力画像中の物体のクラスが既知であるため、検出が容易になるためであると考えられる。

また、認識用 Object Filter において、生成時に用いる p-ROI と n-ROI 数を変えることによる検出結果の影響を調べるため、1 枚の画像から選択される p-ROI と n-ROI の枚数を変えて認識用 Object Filter の物体の検出実験を行う。実験には、各画像から選択する p-ROI 数を p 、n-ROI 数を n とした場合に $p:n$ の比率で生成した認識用 Object Filter を用いる。実験結果を表 3 に示す。表 3 より、認識用 Object Filter の生成時に用いる p-ROI と n-ROI 数が検出率に影響を及ぼし、n-ROI を多くした方が高い検出率が得られることが確認できた。

4.3 Object Filter を用いた認識実験

本研究では、Object Filter 生成時に、原画像と同様のアスペクト比にするため、 8×8 、 10×10 、 12×12 セルに分割した画像を作成する。さらに、縦長 (横長) 画像に対して横長 (縦長) の物体を検出するため、 8×10 と 10×8 セルに分割した画像を生成し、 8×8 セル分の領域を 1 つの候補 ROI として計 41 個の候補 ROI を生成する。原画像と ROI を対象にした認識実験の結果を表 4 に示す。なお、この実験では学習・認識は one-versus-one 手法を用いた。原画像では画像全体、ROI では決定された ROI から HOG を算出する。実験結果を表 4 に示す。表 4 より、原画像を用いた場合の方が ROI 抽出後の画像より高い認識率を得た。これは、Object Filter による

表 4 原画像, ROI を対称にした認識結果

特徴抽出する対象領域	原画像	ROI
認識率 [%]	49.3	40.2

ROI の誤検出に原因があると考えられる。

4.4 Object Filter を利用したマルチ ROI 手法

4.3 の実験において, $p = 1$, すなわち, 候補 ROI とクラスモデル間の距離 d が最小になる候補 ROI を p-ROI として用いた。しかし, クラス内の形状には多様性があり, 距離 $d(X, Y)$ が最小になる候補 ROI が最も正確に物体を含むとは限らないことが 4.1 から推測される。そのため, 学習プロセスにおいて, 各画像から決定する ROI を 1 個ではなく, 複数選択すれば, 正確に物体を含む ROI が学習に利用される確率が高く, 学習データも増え, 学習精度の向上につながる。そこで, クラスモデルとの距離が小さい上位 p 個を p-ROI として学習サンプルに用いる。このように複数の ROI を用いる手法をマルチ ROI 手法とする。図 8 に学習に用いる p-ROI 数 $p = 1 \sim 10$ に設定した場合の認識結果を示す。図 8 では原画像の結果を “Original”, マルチ ROI 手法の結果を “ROI” で示す。“Original” を示す点線はマルチ ROI 手法と比較するための基準となる。図 8 より, ROI 数を増やすことで, 認識率が向上することがわかる。

認識用 Object Filter においても同様に, ROI の誤検出が原因で誤認識判定につながるものが推測される。そのため, 認識プロセスにおいてもマルチ ROI 手法を用いる。ここでは, 認識用 Object Filter の SVM 出力が高い順に複数の ROI を選択する。なお, 認識プロセスにおいてマルチ ROI を認識に用いる場合, 各 ROI に対してクラスの認識判定を行うため, R 個の ROI を抽出した場合, R 個の判定結果が出力される。ここで, R 個中クラス判定の出力値が最大となる ROI の結果を認識結果とする手法を最大出力判定とする。一方で, 選択した全 ROI に対し, 各クラス判定の出力値を累積 (加算) し, 累積出力値が最大となるクラスを最終的な認識結果とする手法を累積出力判定とする。実験結果を図 9 に示す。この実験には, 学習時にもマルチ ROI 手法を用いて, 1 枚の画像から ROI を 10 個選択 ($p = 10$) し, 学習させた識別器を使用している。図 9 では, 原画像を用いた場合の結果を “Original”, 最大出力判定の結果を “max output”, 累積出力判定の結果を “cumulative output” で示す。図 9 より, 認識プロセスにおいて選択する ROI 数を増やすことで, 最大出力判定と累積出力判定の両方で認識率が向上し, 両者とも原画像と比較して認識率を上回ることがわかる。また, 累積出力判定は, 最大出力判定よりも高精度で認識可能であり, マルチ ROI 手法の有効性が確認できた。

4.5 認識用 Object Filter の生成条件を変えた場合の認識実験

4.2 の実験より, 認識用 Object Filter の生成時に用い

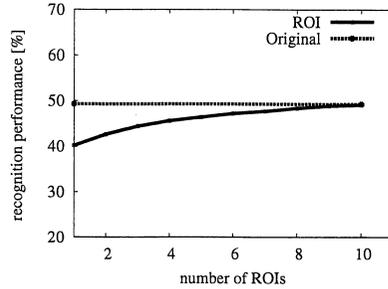


図 8 学習する ROI の枚数による認識率の変動

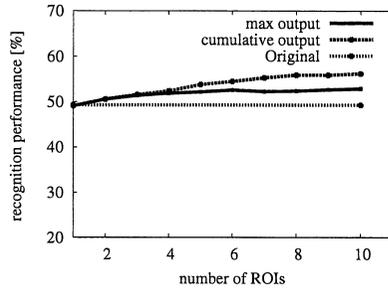


図 9 認識 ROI の枚数変化による認識率の変動

る学習データ数 (p-ROI, n-ROI の数と比率) が, 検出精度に影響を与えることが確認された。ここでは, その検出精度の違いが認識結果にどの程度影響するかを確認し, 最適な学習データ数に関して検討する。そこで, 認識用 Object Filter の生成時に用いる p-ROI と n-ROI 数と比率を変化させた場合の認識実験を行う。1 枚の画像から生成する p-ROI 数を $p = 1 \sim 5$, n-ROI 数を $n = 1 \sim 5$ に変化させた場合の実験結果を図 10 に示す。ここでは, 認識用 Object Filter の性能を認識率で評価するため, クラス識別器を学習する学習データは可能限り高精度の方が良い。そのため, クラス識別器の学習にはマルチ ROI 手法を用い, 1 枚の画像から 10 個の ROI を選択し用いる。図 10 より, 認識用 Object Filter 生成時の学習データ数を変えることにより, 認識率は最低で 46.6%, 最大で 50.9% となり, 最大で 4.3% の差が生じることが確認された。また, 認識率に関しても n-ROI を複数用いる方が効果が高いことが明らかとなった。これより, 認識用 Object Filter 生成時に用いる p-ROI と n-ROI の数とその比率により, 検出結果が変わり, 認識率に影響を及ぼすことを明らかにした。

5. 考 察

提案した Object Filter の検出精度に関して, 本研究での検出率は約 70% であり, 比較的良い検出率が得られたと考えられる。しかし, 認識実験では誤検出した領域を学習・認識に用いてしまうため, 高い認識精度が得ら

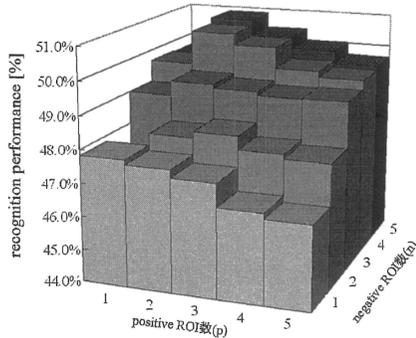


図 10 認識用 Object Filter の学習サンプル数を変えたときの認識率の変化

れない原因にもなっていると考えられる。本研究では候補 ROI 数を 41 個としたが、候補 ROI の形状・大きさのパターンを変えることで、検出精度が改善され、認識精度の向上にもつながると考えられる。一方で、Object Filter を利用したマルチ ROI 手法では、原画像を用いた場合よりも認識率は向上した。このとき、認識プロセスにおいて、累積出力判定を用いた場合の方が最大出力判定より高い認識率が得られた。これは、最大出力判定では、選択する ROI 数を増加することで、正確に物体を含む ROI が得られる確率が高くなるだけでなく、誤抽出された ROI に対するクラス判定の出力値が高くなり、認識率が低下したためと考えられる。これに対して、累積出力判定では、1 つの ROI の出力結果だけでなく、選択した全ての ROI の結果を総合的に判定することで、信頼性が高まると考えられる。また、認識用 Object Filter 生成時の p-ROI と n-ROI 数の比率に関して、n-ROI 数を p-ROI 数よりも多くした場合に認識率は高くなる傾向を確認した。結果的には、n-ROI 数を p-ROI 数の 2 倍以上用いた場合に高い認識率が得られると考えられる。

以上の考察に基づき、学習画像 15 枚と 30 枚の場合に対し、提案手法により一般物体認識実験を行った。Caltech101 を対象にした他の研究の実験結果 [3], [11]~[15] とともに one-versus-all と学習・認識で 10 個の ROI を選択したマルチ手法を用いた実験結果を図 11 に示す。なお、ここでは、Varma らのようにクラス識別器毎に特徴量の重み付けを変える手法等は、比較対象に入れていない。図 11 より、提案手法は学習画像 30 枚の場合で 62.0% と、従来の手法と比較しても良好な認識率が得られた。さらに、提案手法では物体の位置を推定することができる利点もあり、一般物体認識に有用な手法であるといえる。

6. まとめ

本研究では、画像中から物体領域を抽出する手法として Object Filter を提案した。検出・認識実験から Object

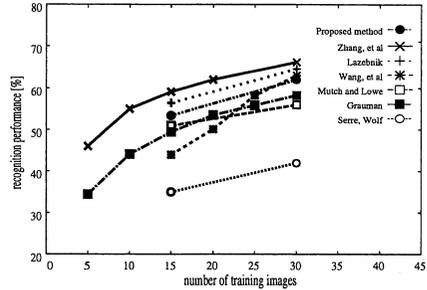


図 11 Caltech101 を用いた他の研究結果との比較

Filter の性能として十分な物体領域の検出と認識が可能であることが確認できた。また、Object Filter を利用したマルチ ROI 手法を用いることで、認識率が向上することを確認し、その有効性を示した。

文 献

- [1] 柳井啓示 “一般物体認識の現状と今後”, 信学技報, PRMU2006-09, pp.121-134(2006).
- [2] G.Csurka, et al, “Visual categorization with bags of keypoint”, In Workshop on Statistical Learning in Computer Vision(ECCV), pp59-74, 2004.
- [3] S.Lazebnik, et al, “Beyond bags of features: Spatial pyramid matching for recognizing natural scene categories”, Proc. IEEE CVPR, pp.2169-2178(2006).
- [4] M.Varma and D.Ray, “Learning The Discriminative Power-Invariance Trade-Off”, Proc. IEEE ICCV, pp1-8, 2007.
- [5] 藤吉弘巨, “Gradient ベースの特徴抽出-sift と hog”, 信学技報, PRMU2007-82, pp.211-223(2007).
- [6] B. N.Dalal, et al, “Histogram of oriented gradients for human detection”, Proc. IEEE CVPR, pp886-893(2005).
- [7] 伊東, 猿田, 寺田, 武田, “改良型 HOG 特徴量による一般物体認識に関する研究”, 電子情報通信学会 2008 年総合大会講演論文集, D-12-55, pp86 2008.
- [8] O.Chum and A.Zisserman, “An exemplar model for learning object classes”, Proc. IEEE CVPR, pp1-8(2007)
- [9] C.Cortes and V.Vapnik, “Support vector networks”, Machine Learning, 20, pp.273-297(1995).
- [10] Intel Corporation, Open Computer Vision Library, <http://www.intel.com/technology/computing/opencv>
- [11] H.Zhang, et al, “SVM-KNN:Discriminative Nearest Neighbor Classification for Visual Category Recognition”, Proc. IEEE CVPR, pp.2126-2136(2006).
- [12] K.Grauman and T.Darrell, “Pyramid match kernel: Discriminative classification with sets of image features”, Proc. IEEE ICCV, pp.1458-1465(2005).
- [13] G.Wang, et al, “Using dependent regions for object categorization in a generative framework”, Proc. IEEE CVPR, pp.1597-1604(2006).
- [14] J.Mutch, and D.Lowe, “Multiclass object recognition using sparse, localized features”, Proc. IEEE CVPR, pp.11-18(2006).
- [15] T.Serre, L.Wolf, and T.Poggio, “Object recognition with feature with features inspired by visual cortex”, Proc. IEEE, pp.994-1000(2005).